

# In-Context Learning に基づく経路案内のための 地理的知識の活用方法に関する検討

高橋健司<sup>1</sup> 高村大也<sup>2</sup> 乾孝司<sup>1</sup>

<sup>1</sup> 筑波大学

<sup>2</sup> 産業技術総合研究所

s2520635@u.tsukuba.ac.jp takamura.hiroya@aist.go.jp inui@cs.tsukuba.ac.jp

## 概要

本稿では、In-Context Learning の枠組みにおいて、大規模言語モデル (LLM) が地理空間上の Point of Interest (POI) 間の位置関係をどのように理解し得るかに着目し、LLM に地理的知識を与える方法について検討した結果を報告する。まず、OpenStreetMap (OSM) から取得した POI データに基づき、POI 間の距離や方位といった地理的位置関係を算出し、それらを地理的知識グラフとして構築・格納する。この準備のもと、知識の表現方法およびその情報量の組合せに着目し、知識グラフを Context として LLM に与える 6 種類の知識パターンを仮定した上で、どのパターンが POI 間の位置関係理解に有効であるかを検討した。地理的関係の理解度を問う 2 種類の推論タスクを設定し、直接的な関係情報が与えられていない POI ペアに対する推論の結果、地理的知識の表現方法および与え方の違いによって、LLM による地理的関係理解の程度が異なることを示す。

## 1 はじめに

近年、LLM の発展は著しく、自然言語の生成や理解において高い性能を示している。質問応答や要約、翻訳など幅広い分野で活用が進んでおり [1] [2] [3]、多様な情報を人間にとって理解しやすい形で表現できる点が大きな利点である。

しかしながら、LLM は空間的な意味関係や地理的情報の処理を必ずしも得意としていないことが指摘されている [4]。特に、地理空間上の POI 間の方向や距離といった地理的関係を正確に把握し、自然言語で説明する能力については十分に検証されていない。これは、LLM が主にテキストデータを基盤として学習しており、座標・距離・方位といった定量的な地理情報を直接扱うようには設計されてい

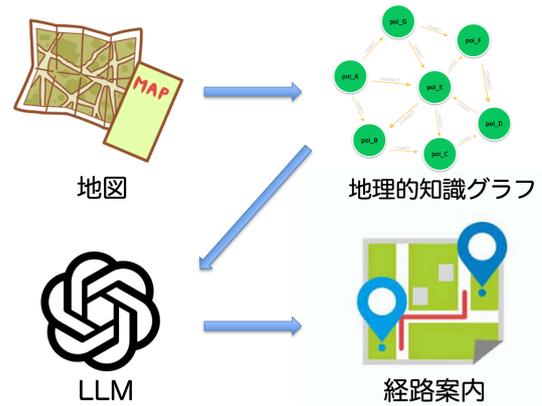


図1 本研究の進め方の概要図

いたためである。

地理的情報の情報源として、OSM をはじめとする地理空間オープンデータは、POI に関する位置関係や距離などの豊富な情報を提供しており、研究や産業分野で広く利用されている。これらを LLM と組み合わせることで、LLM による地理情報の理解と自然言語による表現が可能になると期待される。

本稿では、このような背景のもと、In-Context Learning の枠組みにおいて、LLM が地理空間上の POI 間の位置関係をどのように理解し得るかに着目し、LLM に地理的知識を与える方法論について述べる。本研究の最終的な目標は、図 1 に示すように、地図データを入力としたとき、LLM を介して経路案内のような地理的推論を要する応用を実現することである。このような応用を実現するための要件として、本研究では次の 2 項目を設定する。

1. LLM が地図上の POI 間の位置関係を正確に理解できること。
2. 上記 1 に基づき、LLM が地理的情報を自然言語で人間にわかりやすく説明できること。

本稿は、これらの要件のうち、1 に関するケーススタディの結果を報告するものである。具体的には、

OSM から取得した POI データから地理的知識グラフを構築し、この地理的知識を LLM に In-Context Learning で与えることを考える。このとき、知識の表現方法および情報量が地理的位置関係の理解・推論に与える影響を検証する。

## 2 関連研究

近年、LLM の発展に伴い、空間的・地理的关系を自然言語として理解・推論させる研究 [5] [6] [7] [8] が進んでいる。

Yifan ら [7] は、自然言語による指示に基づいて、GIS の処理手順を自動的に計画・実行する枠組みである GeoGPT を提案した。GeoGPT は、施設立地選定や場所検索などの GIS タスクを、GIS 機能を順に適用することで実現する。一方で、地点間の距離や方位といった位置関係の理解・推論は外部処理に依存しており、言語モデルが地理的关系をどの程度理解できるかは明らかになっていない。

He ら [8] は、衛星リモートセンシング画像中の物体間の空間関係を解析し、LLM によるキャプション生成を行う手法を提案した。提案手法では、画像解析によってあらかじめ抽出された位置関係を、few-shot prompting により与えた規則に基づいて自然言語へ変換する。これに対し本研究では、POI 間の距離や方位といった定量的属性を入力として、LLM 自身がこれらの数値情報を解釈し、位置関係を推論・記述する点で異なる。

## 3 基盤技術

### 3.1 OpenStreetMap (OSM)

OSM [9] は、世界規模で網羅的な地理情報を提供しており、地域や施設種別 (POI) を指定して必要なデータを抽出できる点に特徴がある。また、OSM はオープンデータとして誰でも自由に利用・編集が可能であり、ナビゲーションや都市分析などの実応用においても広く活用されている。本研究では、このような特性を踏まえ、地理的知識の情報源として OSM を利用する。

### 3.2 Neo4j

Neo4j [10] は、ノードとリレーションシップから構成される代表的なグラフデータベースである。地理的知識を扱う場合、ノードは地点や施設などのエンティティを、リレーションシップはそれらの関係

[三つ組データ]

```
(:POI {shop: NaN, amenity: "restaurant", name: "poi_A", tourism: NaN, railway: "stop", public_transport: "stop_position", lat: 36.082628, lon: 140.111214})
```

```
-[:CONNECT {walk_distance: 964.874959503343, straight_distance: 897.2430167864503, angle: 145.17368492217048}]
```

```
->(:POI {shop: NaN, amenity: "events_venue", name: "poi_B", tourism: NaN, railway: NaN, public_transport: NaN, lat: 36.076004, lon: 140.116915})
```

[自然言語文データ]

「poi\_A」は緯度が36.082628で、経度が140.111214です。  
「poi\_B」は緯度が36.076004で、経度が140.116915です。  
「poi\_A」から見て「poi\_B」は145度の方向にあり、直線距離で約897m、徒歩では約965m離れています。

図2 三つ組データと自然言語文データの例

を表し、両者に属性を付与できる。距離や方位といった地理的属性を関係として表現できるため、地理情報のような関係構造を持つデータのモデリングに適している。

## 4 実験データの作成

### 4.1 OSM データの取得と前処理

OSM から茨城県つくば市に所在するつくば駅周辺の POI データを取得した。OSMnx ライブラリ [11] を用いることで、OSM から特定地域の POI を効率的に抽出できる。本研究では、商業施設、公共施設、飲食店を主な対象とし、各 POI の緯度・経度情報を取得した。取得したデータは Python 上で前処理を行い、欠損値および重複データを除去したうえで、POI 名、カテゴリ、緯度・経度を基本属性として保持した。

### 4.2 三つ組データの作成

図2 上に、本研究で用いる POI 間関係の三つ組データの例を示す。前節で取得した POI データを基に、以下の手順により三つ組データを作成した。

まず、OSM から道路網データを取得し、交差点をノード候補、道路をエッジとするグラフ構造として POI データを表現した。各 POI を最寄りの交差点ノードに対応付けることで POI を道路ネットワーク上に配置した。なお、複数の POI が同一の交差点ノードに割り当てられる場合があるが、本研究では

パターン名	知識表現	緯度経度	採用エッジ
パターン 1	三つ組	あり	全エッジ
パターン 2	三つ組	あり	部分エッジ
パターン 3	自然言語文	なし	全エッジ
パターン 4	自然言語文	なし	部分エッジ
パターン 5	自然言語文	あり	全エッジ
パターン 6	自然言語文	あり	部分エッジ

表 1 知識パターン

これを許容した上で、POI 間の経路を実際の道路構造に基づいて特定可能としている。

次に、経路を構成する道路エッジの属性から、直線距離、経路距離、および方位を算出した。これらの情報を用いて POI 対およびそれらの関係を三つ組として定義した。方位は北を 0 度、東を 90 度とする時計回りの基準で表現しており、POI 間のどちらを基点とするかで方位情報が異なるため、POI 対毎に 2 件の三つ組を作成する。後述の実験では、共通する POI 間に張られるこの 2 件 1 組のエッジ対に注目して採用するエッジを選択する。

以上のようにして得られた三つ組データ集合、すなわち知識グラフを Neo4j で管理する。

### 4.3 自然言語文データの作成

後述の実験では、知識表現として、三つ組表現に加えて自然言語表現を採用した。三つ組データは、図 2 下に示すような 3 つの定型文からなる自然言語文データに変換し実験に用いた。この変換は、Flan-T5 に基づく few-shot prompting によって実行した。

## 5 実験設定

### 5.1 知識パターン

LLM に与える地理的知識の知識表現および情報が推論性能に与える影響を検証する。知識表現として三つ組と自然言語文の 2 種類を、また情報量の観点から緯度経度情報の有無および全エッジを用いるか部分エッジを用いるかという 2 つの条件を設定し、これらの組み合わせに基づく表 1 の 6 パターンを比較する。

### 5.2 POI データ

つくば駅周辺からランダムに選出した実在の POI 情報に基づく 10 個の POI を用いた。LLM が事前学

あなたは地理情報をもとに経路案内を行うアシスタントです。以下に与えられる地理的知識から質問に答えてください。

#### [地理的知識]

「poi\_A」から見て「poi\_B」は145度の方向にあり、直線距離で約897m、徒歩では約965m離れています。

「poi\_B」から見て「poi\_C」は309度の方向にあり、直線距離で約1359m、徒歩では約1429m離れています。

⋮

#### [質問]

poi\_A から poi\_C へは、どの方角に何m程度ですか？

図 3 入力プロンプトの例 (実際の実験では、6 パターンの知識表現に応じて、入力プロンプト中のエッジ数および内容を変更している。)

習によって保持している実世界知識を参照することを防ぐため、各 POI の名称は実際の名称を用いず、poi\_A から poi\_J までの記号的な名称にマスクした。

### 5.3 部分エッジの決定方法

POI 間の関係を三つ組および自然言語文として LLM に与える際、POI の全組み合わせ (全エッジ) を対象とすると、POI 数が 10 のとき、エッジは  $(10 \times 9) / 2 = 45$  組となり、データ量は  $O(n^2)$  となる。そこで、エッジの全組合せから各エッジの向きを無視した完全グラフに対して、最小全域木 (MST) [12] を構築し、MST に含まれるエッジのみを与える設定を試す。MST は、全ての POI を連結する最小限のエッジ集合であるため、直接的な関係が与えられていない POI 間についても、他の POI を経由して関係を辿ることが可能であると考えられる。この性質により、POI 数が 10 のとき、LLM に与えるエッジは 9 組となり、すなわちデータ量を  $O(n)$  まで削減することができる。

### 5.4 評価タスク

LLM の理解度評価のケーススタディとして、以下の 2 種類のタスクを用いた。

**タスク 1:** 「poi\_A から徒歩距離が 1km 以内に存在する POI はどれか」 (正解: poi\_B, poi\_C, poi\_F)

**タスク 2:** 「poi\_A から poi\_C へは、どの方位に何 m 程度か」 (正解: 283 度の方向に約 556m)

タスク 1 では距離に基づく空間的近接関係の理解を、タスク 2 では方向および距離を統合した相対位置関係の理解能力を評価する。なお、正解値に対して、距離および方位の誤差がともに  $\pm 5\%$  以内に

パターン	タスク 1	タスク 2	主な挙動・特徴
1	0/9	0/9	未入力 POI 間を推論したものの、距離・方位の統合はできなかった。
2	0/9	0/9	MST によるエッジ削減は、全エッジ条件と同一の結果となった。
3	9/9	5/9	相対的な位置推定は行えたが、265 度の 526m と多少の誤差が生じた。
4	9/9	5/9	MST を用いても、相対位置推定の精度に大きな差は見られなかった。
5	9/9	9/9	緯度・経度情報により、未入力 POI 間でも正確な推論が可能であった。
6	9/9	9/9	MST によるエッジ削減後も、パターン 5 と同等の推論精度が得られた。

表 2 実験結果

収まる場合を正答とみなした。基準とする POI を poi.A 以外のものに変更した場合についても同様の評価を行ったが、結果の傾向に大きな差は見られなかったため、代表例として本稿では上述のタスクのみを示す。

評価では、LLM に与えるエッジのうち 1 組の関係情報を入力から除外して評価を行った。評価条件を統一するため、全エッジ設定においては、未入力とするエッジを MST に含まれる 9 組のエッジのいずれかとし、未入力とするエッジを切り替え、タスク毎に計 9 回の推論実験を試行した。

今回は GPT-5 を評価対象 LLM とし、図 3 のようなプロンプトを与えた。この図は知識パターン 3 において評価タスク 2 を実行した際のプロンプト例である。

## 6 実験結果と考察

実験結果を表 2 に示す。

### 6.1 全エッジを採用したとき

パターン 1 の三つ組表現では、距離や方位といった数値情報がグラフ構造上の属性として個別に与えられるため、LLM がそれらを空間的意味を持つ関係として文脈的に解釈することが困難であることが示唆される結果であった。本実験で用いた三つ組データには各 POI の緯度・経度情報も含まれていたが、これらはノード属性や関係属性として分散して与えられるため、統合的な空間推論には十分に活用されなかったと考えられる。

パターン 3 の緯度・経度情報を含まない自然言語文では、LLM は距離や方位といった相対的情報を手がかりに、POI 間の位置関係を推定する挙動を示した。タスク 1 では正確な回答が可能であったが、タスク 2 では絶対的な座標系が与えられていない条件下で推定を行う必要があり、その結果として誤差が発生してしまい、正確な結果を出力することがで

きなかった。

パターン 5 の緯度・経度情報を含む自然言語文を与えた場合、LLM は POI 間の位置関係を一貫して正確に推論できた。これは、全 POI が共通の地理座標系上に明示的に配置されることで、POI 間の相対的な位置関係を逐次的に辿る必要がなくなり、位置関係を直接的に把握できるようになったためであると考えられる。

### 6.2 部分エッジを採用したとき

パターン 2, 4, 6 における MST を用いて POI 間のエッジ数を削減した場合でも、全エッジを与えた場合と同等の推論結果が得られた。このことから、LLM による地理的推論では、全ての POI 間関係を与える必要はなく、連結性を保つ最小限の関係集合である MST に基づく知識表現でも、十分な推論精度が維持されることが示された。

## 7 おわりに

実験結果より、緯度・経度情報を含まない自然言語文であっても、一定程度の経路案内に必要な地理関係理解が可能であることが示唆される。一方で、高精度な地理関係理解を実現するためには、緯度・経度情報を含む自然言語表現が有効であることが示された。また、MST に基づく部分エッジを採用した場合でも、全エッジを与えた場合と同等の推論結果が得られ、位置関係に関する知識の準備コストを抑制できることが示唆された。

本研究は、LLM が地理的關係を理解し自然言語で説明できる可能性を示す初歩的成果である。今後の主な課題として、以下が挙げられる。

- 道路情報や周囲の目印となる看板等を、LLM が適切に理解・活用できる入力形式の検討。
- RAG と統合し、地図情報検索と経路説明生成を連携させる手法の確立。

## 謝辞

本研究は JSPS 科研費 25K03225 の助成を受けたものです。

## 参考文献

- [1] Andrea Matarazzo, and Riccardo Torlone. “A Survey on Large Language Models with some Insights on their Capabilities and Limitations.” arXiv preprint arXiv:2501.04040, 2025.
- [2] Wenhao Zhu, Hongyi Liu, Qingxiu Dong, Jingjing Xu, Shujian Huang, Lingpeng Kong, Jiajun Chen, and Lei Li. “Multilingual Machine Translation with Large Language Models: Empirical Results and Analysis.” arXiv preprint arXiv:2304.04675, 2024.
- [3] Jonas Becker, Jan Philip Wahle, Bela Gipp, and Terry Ruas. “Text Generation: A Systematic Literature Review of Tasks, Evaluation, and Challenges.” arXiv preprint arXiv:2405.15604, 2024.
- [4] Nir Fulman, Abdulkadir Memduhoğlu, and Alexander Zipf. “Distortions in Judged Spatial Relations in Large Language Models.” arXiv preprint arXiv:2401.04218, 2024.
- [5] Jiaqi Chen, Bingqian Lin, Ran Xu, Zhenhua Chai, Xiaodan Liang, and Kwan-Yee K. Wong. “MapGPT: Map-Guided Prompting with Adaptive Path Planning for Vision-and-Language Navigation.” arXiv preprint arXiv:2401.07314, 2024.
- [6] Jingping Liu, Ziyang Liu, Zhedong Cen, Yan Zhou, Yanan Zou, Weiyan Zhang, Haiyun Jiang, and Tong Ruan. “Can Multimodal Large Language Models Understand Spatial Relations?” arXiv preprint arXiv:2505.19015, 2025.
- [7] Yifan Zhang, Cheng Wei, Shangyou Wu, Zhengting He, and Wenhao Yu. “GeoGPT: Understanding and Processing Geospatial Tasks through an Autonomous GPT.” arXiv preprint arXiv:2307.07930, 2023.
- [8] Yingxu He, and Qiqi Sun. “Towards Automatic Satellite Images Captions Generation Using Large Language Models.” arXiv preprint arXiv:2310.11392, 2023.
- [9] Grinberger, A. Y., Minghini, M., Juhász, L., Yeboah, G., and Mooney, P. “OSM Science — The Academic Study of the OpenStreetMap Project, Data, Contributors, Community, and Applications.” ISPRS International Journal of Geo-Information, 11(4):230, 2022.
- [10] Besta, M., Gerstenberger, R., Peter, E., Fischer, M., Podstawski, M., Barthels, C., Alonso, G., and Hoeffler, T. “Demystifying Graph Databases: Analysis and Taxonomy of Data Organization, System Designs, and Graph Queries.” arXiv preprint arXiv:1910.09017, 2019.
- [11] Boeing, G. “OSMnx: A Python package to work with graph-theoretic OpenStreetMap street networks.” Journal of Open Source Software, vol.2, no.12, p.215, 2017.
- [12] R. C. Prim. “Shortest Connection Networks and Some Generalizations.” Bell System Technical Journal, 36(6):1389–1401, 1957.